



Diagnosa Penyakit Tanaman Tomat pada Citra Daun Menggunakan Metode Convolutional Neural Network (CNN)

Ananda Maysela Nur Rohma
Teknik Informatika, Universitas Muhammadiyah Ponorogo
Email: anandasela85@gmail.com

Article Info

Article history:

Received May 25, 2024
Revised May 29, 2024
Accepted June 12, 2024

Keywords:

CNN; disease detection;
tomato plants; digital
image; leaf images

ABSTRACT

A Convolutional Neural Network (CNN) was employed to identify diseases in tomato plants through leaf images. The dataset comprised 10,000 images, divided into three parts: 85% for training, 10% for validation, and 5% for testing. Data preprocessing included resizing and labeling images according to their disease type. The CNN model utilized DenseNet121 for feature extraction, leveraging weights pre-trained on the ImageNet dataset. The testing results showed a validation accuracy of 93%, indicating that the model can accurately identify tomato leaf diseases. This study demonstrates that CNNs can improve the efficiency and effectiveness of plant disease detection compared to traditional methods.

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



Article Info

Article history:

Received May 25, 2024
Revised May 29, 2024
Accepted June 12, 2024

Keywords:

CNN; deteksi penyakit;
tanaman tomat; citra
digital; citra daun

ABSTRACT

Penggunaan Convolutional Neural Network (CNN) telah diterapkan untuk mengidentifikasi penyakit pada tanaman tomat melalui citra daun. Dataset terdiri dari 10.000 gambar yang dibagi menjadi tiga bagian: 85% untuk data pelatihan, 10% untuk data validasi, dan 5% untuk data uji. Proses praproses data mencakup pengubahan ukuran (resize) dan pelabelan gambar sesuai dengan jenis penyakitnya. Model CNN yang digunakan diinisialisasi dengan DenseNet121 sebagai extractor fitur, menggunakan bobot yang telah dilatih sebelumnya pada dataset ImageNet. Hasil pengujian menunjukkan akurasi validasi sebesar 93%, menandakan model ini mampu mengidentifikasi penyakit daun tomat dengan tingkat akurasi yang tinggi. Penelitian ini menunjukkan bahwa penggunaan CNN dapat meningkatkan efisiensi dan efektivitas dalam deteksi penyakit tanaman dibandingkan dengan metode tradisional.

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



Corresponding Author:

Nama penulis: Ananda Maysela Nur Rohma
Universitas Muhammadiyah Ponorogo
Email : anandasela85@gmail.com



Pendahuluan

Pertanian memiliki peran yang sangat vital dalam upaya meningkatkan perekonomian Indonesia. Secara keseluruhan, sektor pertanian terbagi ke dalam beberapa subsektor, yaitu subsektor hortikultura, perkebunan, dan pangan. Subsektor hortikultura, yang mencakup buah-buahan dan sayuran, adalah bagian penting dari sektor pertanian dan merupakan salah satu kontributor signifikan dalam peningkatan Produk Domestik Bruto (PDB). Salah satu tanaman hortikultura yang memiliki potensi besar adalah tomat (*Lycopersicon esculentum* Mill), yang dikenal sebagai sayuran serba guna dengan berbagai manfaat [1].

Tomat adalah tanaman hortikultura yang populer di kalangan masyarakat karena memiliki nilai ekonomi yang tinggi sebagai bahan untuk olahan makanan, minuman, sayuran, buah-buahan, dan kosmetik. Menurut data dari Badan Pusat Statistik Nasional (BPS) tahun 2019, produktivitas tanaman tomat telah meningkat sebesar 24% dalam empat tahun terakhir. Peningkatan ini harus didukung dengan upaya menjaga kualitas dan kuantitas produksi tomat mulai dari proses penanaman hingga panen.

Daun tanaman tomat memiliki peran dan fungsi yang sangat penting dalam proses pertumbuhan tanaman. Penyakit yang menyerang daun dapat menjadi salah satu faktor yang mempengaruhi pertumbuhan tanaman secara keseluruhan. Ketika daun terserang penyakit, hal ini akan membahayakan kondisi tanaman dan mempengaruhi hasil produksi panen. Jenis penyakit pada daun dapat dikenali dari gejalanya yang berbeda-beda, meskipun gejala tersebut tidak selalu dapat menjelaskan dengan tepat nama penyakit yang menyerang. Hal ini disebabkan oleh banyaknya jenis penyakit yang memiliki gejala serupa dan hampir terlihat sama. Identifikasi penyakit pada daun tanaman tomat umumnya dilakukan di laboratorium, yang membutuhkan waktu dan biaya yang cukup besar [2].

Beberapa penelitian terkait pendeteksian penyakit pada tanaman telah dilakukan, salah satunya dengan judul "Identifikasi Penyakit Pada Tanaman Tomat Berdasarkan Warna dan Bentuk Daun dengan Metode *Naive Bayes Classifier* Berbasis Web". Penelitian ini fokus pada identifikasi penyakit pada daun tomat melalui proses ekstraksi fitur warna dan bentuk menggunakan HSV (*Hue, Saturation, Value*) dan operator Sobel, dengan hasil keberhasilan sebesar 82,98% [3].

Penelitian lainnya yang berjudul "*Detection of Affected Part of Plant Leaves and Classification of Diseases Using CNN Technique*" membahas tentang pendeteksian penyakit daun menggunakan teknik CNN (*Convolutional Neural Network*). Awalnya, penelitian tersebut menggunakan *Bilateral Filter* untuk menghilangkan *noise* pada citra. Selanjutnya, dilakukan segmentasi menggunakan metode FCM (*Fuzzy C-Means*), diikuti oleh ekstraksi fitur tekstur menggunakan GLCM (*Gray Level Co-Occurrence Matrix*) dan RLM (*Run Length Matrix*). Proses akhir melibatkan klasifikasi menggunakan CNN. Hasil penelitian menunjukkan tingkat akurasi sebesar 98%, tingkat presisi sebesar 96%, tingkat kesalahan sebesar 2%, dan tingkat recall sebesar 97% [4].

Dalam penelitian ini, penulis mengidentifikasi penyakit pada tanaman tomat melalui citra daun menggunakan deep learning dengan metode *Convolutional Neural Network* yang telah dimodifikasi.

Tinjauan Pustaka

a. Tanaman Tomat


Tomat, yang secara ilmiah dikenal sebagai *Lycopersicon esculentum* Mill, adalah jenis sayuran buah yang termasuk dalam keluarga *Solanaceae* dan tumbuh sebagai tanaman semusim dengan bentuk perdu. Buah tomat merupakan sumber yang kaya akan vitamin dan mineral. Penggunaannya semakin luas karena tidak hanya dikonsumsi sebagai tomat segar atau bumbu masakan, tetapi juga dapat diolah lebih lanjut menjadi berbagai produk makanan seperti sari buah dan saus tomat [5].

Meskipun proses pembudidayaan tanaman tomat dianggap relatif mudah, tanaman ini tetap rentan terhadap serangan penyakit yang disebabkan oleh berbagai faktor seperti bakteri, jamur, virus, serta serangga atau hama. Gejala penyakit pada tanaman tomat biasanya dapat diamati melalui perubahan warna dan bentuk pada berbagai bagian tanaman, mulai dari daun, batang, hingga buahnya. Namun, seringkali gejala penyakit terutama dapat terlihat melalui daun. Berbagai jenis penyakit yang dapat menyerang tanaman tomat meliputi *bacterial spot*, *early blight*, *late blight*, *leaf mold*, *septoria leaf spot*, *spider mites*, *target spot*, *yellow leaf curl virus*, *mosaic virus*, serta berbagai penyakit lainnya [6].

b. Metode Convolutional Neural Network

Penemuan *Convolutional Neural Network* (CNN) pertama kali dilakukan oleh Hubel dan Wiesel yang meneliti korteks visual pada indera penglihatan kucing. CNN secara teknis adalah sebuah arsitektur yang dapat dilatih dan terdiri dari beberapa tahap, yaitu masukan (*input*) dan keluaran (*output*) [7].

Secara teknis, CNN melatih dan menguji setiap gambar masukan melalui serangkaian proses, yaitu lapisan konvolusi (*convolutional layer*) yang diikuti oleh *pooling* untuk mengekstraksi fitur dari gambar masukan secara bertahap. Setelah operasi *pooling*, citra di-flatten dan kemudian dimasukkan ke proses *fully connected layer* untuk melaksanakan tugas pengklasifikasian. Arsitektur yang menggambarkan proses-proses yang terjadi pada metode CNN dapat dilihat pada Gambar 1 [8].



Gambar 1. Representasi Arsitektur *Convolutional Neural Network*

Metodologi

a. Pengumpulan Data

Untuk mengklasifikasikan penyakit pada tanaman tomat, diperlukan gambar atau foto penyakit tanaman tomat yang diambil dari dataset di *Kaggle*. Penyakit tanaman tomat yang akan diklasifikasikan atau diidentifikasi dalam penelitian ini dibagi menjadi dua kategori: sehat dan tidak sehat, dengan total 10000 gambar. Gambar-gambar ini akan digunakan sebagai data pelatihan dan data validasi, dengan format yang digunakan adalah jpg. Contoh data yang digunakan dalam penelitian ini dapat dilihat sebagai berikut:



Gambar 2. Penyakit *Bacterial Spot*



Gambar 3. Penyakit *Early Blight*



Gambar 4. Penyakit *Late Blight*



Gambar 5. Penyakit *Leaf Mold*



Gambar 6. Penyakit *Septoria Leaf Spot*



Gambar 7. Penyakit *Spider Mites*



Gambar 8. Penyakit *Target Spot*



Gambar 9. Penyakit *Yellow Leaf Curl Virus*



Gambar 10. Penyakit *Mosaic Virus*



Gambar 10. Sehat

Metode yang digunakan dalam penelitian ini untuk mendeteksi objek terdiri dari tiga tahapan, yaitu *input*, *process*, dan *output*:

Tabel 1. Dataset Kategori Daun Tomat

No	Nama Penyakit	Jumlah
1	<i>Bacterial spot</i>	1000
2	<i>Early blight</i>	1000
3	<i>Late blight</i>	1000
4	<i>Leaf mold</i>	1000
5	<i>Septoria leaf spot</i>	1000
6	<i>Spider mites</i>	1000
7	<i>Target spot</i>	1000



8	<i>Yellow leaf curl virus</i>	1000
9	<i>Mosaic virus</i>	1000
10	<i>Healthy</i>	1000
Jumlah		10000

Pada Tabel 1 terdapat sepuluh kelas dengan total 10.000 citra. Dalam penelitian ini, data dibagi menjadi tiga bagian: 85% data sebanyak 8.500 citra digunakan sebagai data pelatihan, 10% data sebanyak 1.000 citra digunakan sebagai data validasi, dan 5% data sebanyak 500 citra digunakan sebagai data uji.


b. Proses Pengolahan Citra

Pada tahap ini, proses pengolahan citra penyakit tanaman tomat telah selesai. Proses yang dilakukan mencakup *resize*, pelabelan dataset, Pembagian data, *data training*, dan *data testing*.

1. *Resize* adalah tahap awal dalam proses *preprocessing* di mana data citra diambil dari dataset yang tersedia dan kemudian diubah ukurannya. Untuk memperkecil ukuran citra secara horizontal dan/atau vertikal, gambar akan di-*resize* sehingga tidak lebih dari 256 x 256 piksel. Langkah ini dilakukan untuk membuat proses pelatihan lebih ringan dan cepat.
2. Pelabelan dataset, data citra yang telah di-*resize* kemudian diberi label berdasarkan nama folder tempat data tersebut disimpan. Misalnya, data dari folder "Tomat *bacterial spot*" akan diberi label "Tomat *bacterial spot*".
3. Pembagian data, data citra yang telah diberi label kemudian akan dibagi secara acak sesuai dengan persentase yang telah ditentukan, yaitu 85% untuk data pelatihan, 10% untuk data validasi, dan 5% untuk data uji.
4. *Data training*, data citra yang telah diberi label dan dibagi sesuai persentase digunakan untuk melatih model secara berulang-ulang hingga proses pelatihan selesai.
5. *Data Testing* dan evaluasi, model yang telah terbentuk dari proses pelatihan kemudian diuji untuk menentukan apakah model dapat mengidentifikasi penyakit dengan akurat. Berdasarkan hasil pengujian, evaluasi akan dilakukan.

c. Desain Model *Convolutional Neural Network*

Pada tahap ini, metode CNN diterapkan melalui beberapa tahap: persiapan data, *data pre-processing*, *data splitting*, perancangan arsitektur, pengaturan parameter, pengujian model, dan evaluasi. Semua tahap tersebut dapat digambarkan dengan diagram alir berikut.



Gambar 11. Diagram Alir Model CNN

Pada diagram alir di Gambar 11, data citra daun tomat diproses terlebih dahulu dengan mengubah ukuran dimensi citra. Selanjutnya, data dibagi menjadi dua bagian, yaitu data latih dan data uji. Dalam perancangan arsitektur dan model CNN, parameter diatur untuk mencapai akurasi yang diinginkan. Jika hasil pengujian menunjukkan akurasi model $> 85\%$, proses dilanjutkan dengan evaluasi. Namun, jika akurasi model $< 85\%$, parameter diatur ulang pada arsitektur CNN hingga akurasi di atas 85% tercapai.

Hasil dan Pembahasan

Pada bagian ini dibahas analisis penelitian dan temuan-temuan terbaru. Hasil percobaan atau eksperimen dan analisis tersebut dievaluasi untuk menentukan apakah sesuai dengan hipotesis (jika ada). Hasil dibahas dengan mengacu pada referensi yang digunakan.



Gambar 12. Beberapa Dataset yang Berhasil Dimuat

Dataset berhasil dimuat ke dalam *Google Colab*, kemudian diubah ukurannya menjadi 256 x 256 piksel. Selanjutnya, data tersebut diberi label sesuai dengan jenis penyakitnya, seperti yang terlihat pada Gambar 12.

```
[ ] conv_base = DenseNet121(  
    weights='imagenet',  
    include_top = False,  
    input_shape=(256,256,3),  
    pooling='avg'  
)
```

Gambar 13. Kode Inisialisasi Model Menggunakan *DenseNet121*

Tahap selanjutnya adalah menginisialisasi model menggunakan *DenseNet121* dengan bobot yang telah dilatih sebelumnya pada dataset *ImageNet*. Argumen *include_top=False* menentukan bahwa model tidak akan memasukkan lapisan terhubung penuh di bagian atas jaringan, yang biasanya digunakan untuk klasifikasi *ImageNet*. Argumen *input_shape=(256,256,3)* menentukan bentuk gambar masukan yang diharapkan oleh model, yaitu 256x256 piksel dengan 3 saluran (RGB). Model yang diinisialisasi, *conv_base*, dapat digunakan sebagai *extractor* fitur untuk mengekstrak fitur dari gambar, yang kemudian dapat digunakan sebagai masukan untuk kepala klasifikasi kustom.



Layer (type)	Output Shape	Param #	Connected to
input_1 (InputLayer)	[(None, 256, 256, 3)]	0	[]
zero_padding2d (ZeroPadding2D)	(None, 262, 262, 3)	0	['input_1[0][0]']
conv1/conv (Conv2D)	(None, 128, 128, 64)	9408	['zero_padding2d[0][0]']
conv1/bn (BatchNormalization)	(None, 128, 128, 64)	256	['conv1/conv[0][0]']
conv1/relu (Activation)	(None, 128, 128, 64)	0	['conv1/bn[0][0]']
zero_padding2d_1 (ZeroPadding2D)	(None, 130, 130, 64)	0	['conv1/relu[0][0]']
pool1 (MaxPooling2D)	(None, 64, 64, 64)	0	['zero_padding2d_1[0][0]']
conv2_block1_0_bn (BatchNormalization)	(None, 64, 64, 64)	256	['pool1[0][0]']
conv2_block1_0_relu (Activation)	(None, 64, 64, 64)	0	['conv2_block1_0_bn[0][0]']
conv2_block1_1_conv (Conv2D)	(None, 64, 64, 128)	8192	['conv2_block1_0_relu[0][0]']
conv2_block1_1_bn (BatchNormalization)	(None, 64, 64, 128)	512	['conv2_block1_1_conv[0][0]']
conv2_block1_1_relu (Activation)	(None, 64, 64, 128)	0	['conv2_block1_1_bn[0][0]']
conv2_block1_2_conv (Conv2D)	(None, 64, 64, 32)	36864	['conv2_block1_1_relu[0][0]']
conv2_block1_concat (Concatenate)	(None, 64, 64, 96)	0	['pool1[0][0]', 'conv2_block1_2_conv[0][0]']
conv2_block2_0_bn (BatchNormalization)	(None, 64, 64, 96)	384	['conv2_block1_concat[0][0]']
conv2_block2_0_relu (Activation)	(None, 64, 64, 96)	0	['conv2_block2_0_bn[0][0]']
conv2_block2_1_conv (Conv2D)	(None, 64, 64, 128)	12288	['conv2_block2_0_relu[0][0]']
avg_pool (GlobalAveragePooling2D)	(None, 1024)	0	['conv2_block2_1_conv[0][0]']

=====
 Total params: 7037504 (26.85 MB)
 Trainable params: 0 (0.00 Byte)
 Non-trainable params: 7037504 (26.85 MB)
 =====


Gambar 14. Parameter Model CNN

Gambar diatas mengilustrasikan fungsi aktivasi yang diterapkan saat melatih model CNN untuk melakukan identifikasi penyakit pada tanaman tomat melalui citra daun. Fungsi aktivasi yang digunakan dalam proses tersebut adalah *Rectification Linear Unit (ReLU)*. Proses pelatihan model CNN untuk identifikasi penyakit pada tanaman tomat memerlukan total 7.037.504 parameter. Jumlah parameter yang besar ini membuat proses kalkulasi memakan waktu dan tenaga yang besar bagi manusia, sementara mesin mampu melakukan perhitungan dengan cepat dan efisien.


Epoch 1/100	313/313 [=====] - 2349s 7s/step - loss: 0.5720 - accuracy: 0.8067 - val_loss: 0.3239 - val_accuracy: 0.8930
Epoch 2/100	313/313 [=====] - 2321s 7s/step - loss: 0.2251 - accuracy: 0.9237 - val_loss: 0.2085 - val_accuracy: 0.9250
Epoch 3/100	313/313 [=====] - 2322s 7s/step - loss: 0.1715 - accuracy: 0.9414 - val_loss: 0.1725 - val_accuracy: 0.9340
Epoch 4/100	313/313 [=====] - 2297s 7s/step - loss: 0.1276 - accuracy: 0.9539 - val_loss: 0.1587 - val_accuracy: 0.9430
Epoch 5/100	313/313 [=====] - 2326s 7s/step - loss: 0.1035 - accuracy: 0.9651 - val_loss: 0.1474 - val_accuracy: 0.9450
Epoch 6/100	313/313 [=====] - 2268s 7s/step - loss: 0.0933 - accuracy: 0.9688 - val_loss: 0.1849 - val_accuracy: 0.9340

Gambar 15. Hasil *Data Training*

Akurasi validasi 93% berarti bahwa ketika model dievaluasi pada seperangkat data terpisah yang tidak pernah dilihat selama pelatihan atau validasi, model tersebut memprediksi hasil dengan benar sebanyak 93% dari waktu. Ini adalah hasil yang baik dan menunjukkan bahwa model tersebut berfungsi dengan baik dan mampu menggeneralisasi dengan baik ke data baru yang belum pernah dilihat sebelumnya.



Gambar 16. Grafik Model *Training* dan *Validation Loss*



Gambar 17. Grafik Model *Training* dan *Validation Accuracy*

Berdasarkan Gambar 16 dan 17, dapat dilihat bahwa proses pelatihan mencapai akurasi 96% dengan nilai *loss* 0,09%. Di sisi lain, akurasi validasi tercatat sebesar 93,4% dengan nilai *loss* 0,18%. Dari data akurasi ini, diketahui bahwa waktu yang diperlukan untuk pelatihan selama 6 *epoch* adalah 37,8 menit. Semakin banyak *epoch* yang digunakan, semakin lama waktu yang dibutuhkan untuk pelatihan.



Simpulan

Model *Convolutional Neural Network* (CNN) yang dikembangkan untuk mendiagnosis penyakit pada tanaman tomat melalui citra daun menunjukkan hasil yang memuaskan. Dengan dataset yang terdiri dari 10.000 gambar, data dibagi menjadi data latih, validasi, dan uji dengan proporsi masing-masing 85%, 10%, dan 5%. Setelah melalui tahapan seperti *resize*, pelabelan dataset, dan pembagian data, proses pelatihan model menghasilkan akurasi validasi sebesar 93%.

Hasil ini menunjukkan bahwa model CNN mampu mengidentifikasi penyakit pada daun tomat dengan tingkat akurasi yang tinggi. Model yang diinisialisasi dengan *DenseNet121* sebagai extractor fitur, memanfaatkan bobot yang telah dilatih sebelumnya pada dataset *ImageNet*, sehingga dapat menangani klasifikasi dengan baik. Proses evaluasi juga menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data baru yang belum pernah dilihat sebelumnya.

Dengan demikian, pendekatan ini memberikan kontribusi signifikan dalam deteksi penyakit tanaman, khususnya tomat, dengan mengurangi waktu dan biaya dibandingkan metode konvensional di laboratorium. Pengembangan lebih lanjut dapat dilakukan dengan menggunakan dataset yang lebih besar dan beragam, serta mengoptimalkan arsitektur dan parameter model untuk meningkatkan akurasi dan efisiensi.

Daftar Referensi

- [1] C. R. Kotta, D. Paseru dan M. Sumampouw, “Implementasi Metode Convolutional Neural Network untuk Mendeteksi Penyakit pada Citra Daun Tomat,” *Jurnal Pekommas*, vol. 7, no. 2, pp. 123-132, 2022.
- [2] R. H. Saputra, R. C. Sigitta Hariyono dan F. , “Deteksi Penyakit Tomat Melalui Citra Daun menggunakan Metode Convolutional Neural Network,” *Aviation Electronics, Information Technology, Telecommunications, Electricals, Controls (AVITEC)*, vol. 5, no. 1, pp. 43-51, 2023.
- [3] F. Alviansyah, I. Ruslianto dan M. Diponegoro, “Identifikasi Penyakit Pada Tanaman Tomat Berdasarkan Warna Dan Bentuk Daun Dengan Metode Naive Bayes Classifier Berbasis Web,” *Jurnal Coding Sistem Komputer Untan*, vol. 5, no. 1, pp. 23-32, 2017.
- [4] A. Blessy dan . D. D. J. W. Wise, “Detection of Affected Part of Plant Leaves and Classification of Diseases Using CNN Technique,” *International Journal of Engineering and Techniques*, vol. 4, no. 2, pp. 823-829, 2018.
- [5] C. Wasonowati, “Meningkatkan Pertumbuhan Tanaman Tomat (*Lycopersicon Esculentum*) Dengan Sistem Budidaya Hidroponik,” *AGROVIGOR*, vol. 4, no. 1, pp. 21-28, 2011.
- [6] A. W. Putri, “Implementasi Artificial Neural Network (ANN) Backpropagation Untuk Klasifikasi Jenis Penyakit Pada Daun Tanaman Tomat,” *Jurnal Ilmiah Matematika*, vol. 9, no. 2, pp. 344-350, 2021.



- [7] A. Escontrela, “Convolutional Neural Networks from the ground up,” Towards Data Science, 17 Juni 2018. [Online]. Available: <https://towardsdatascience.com/convolutional-neural-networks-from-the-ground-up-c67bb41454e1>. [Diakses 14 Juni 2024].
- [8] P. Raghav, “Understanding of Convolutional Neural Network (CNN) — Deep Learning,” Medium, 4 Maret 2018. [Online]. Available: <https://medium.com/@RaghavPrabhu/understanding-of-convolutional-neural-network-cnn-deep-learning-99760835f148>. [Diakses 14 Juni 2024].